

水系统数字化与智能化

沈浩, 信昆仑. 基于深度学习的污水处理厂生物反应池状态预测[J]. 净水技术, 2026, 45(3): 133-138.

Shen H, Xin K L. State prediction of biological reactor based on deep learning in WWTP[J]. Water Purification Technology, 2026, 45(3): 133-138.

基于深度学习的污水处理厂生物反应池状态预测

沈浩^{1,*}, 信昆仑²

(1. 宁波水务环境集团有限公司, 浙江宁波 315800; 2. 同济大学环境科学与工程学院, 上海 200092)

摘要 【目的】 面对污水处理排放标准日益趋严以及运行成本持续上升的现实, 借助智能化技术实现污水处理厂稳定运行与节能降耗已成为行业面临的迫切挑战。针对传统机理模型在复杂生物反应过程中适应性不足的问题, 开展基于数据驱动的状态预测研究具有重要工程意义。【方法】 本文针对某污水厂厌氧-缺氧-好氧活性污泥工艺, 构建了长短期记忆(LSTM)网络状态预测模型。通过对实际运行历史数据进行清洗、归一化等, 建立符合时间序列特征的模型输入输出结构。模型以进水水质指标、反应池运行状态变量与控制参数作为输入, 通过挖掘多变量时序数据中的动态关联特征, 实现了对溶解氧(DO)与混合液悬浮固体(MLSS)等关键水质与运行参数的精准预测。【结果】 LSTM网络模型在预测精度、稳定性与鲁棒性方面均显著优于传统循环神经网络与多层感知机模型; 同时, 适当增加网络复杂度与训练数据量, 可进一步提升模型的预测性能与泛化能力。【结论】 本文不仅验证了深度学习在污水处理时序预测中的有效性和可行性, 也为前馈补偿控制与滚动优化控制等智能运行策略提供了可靠的生物反应池状态预测基础, 为构建数据驱动的闭环优化控制系统提供了可行技术路径, 对推动污水厂智能化、低碳化运行具有积极意义。

关键词 污水处理厂(WWTP) 深度学习 长短期记忆(LSTM)网络 生物反应池 状态预测

中图分类号: TU992 **文献标志码:** A **文章编号:** 1009-0177(2026)03-0133-06

DOI: 10.15890/j.cnki.jsjs.2026.03.013

State Prediction of Biological Reactor Based on Deep Learning in WWTP

Shen Hao^{1,*}, Xin Kunlun²

(1. Ningbo Water and Environment Group Co., Ltd., Ningbo 315800, China;

2. College of Environmental Science and Engineering, Tongji University, Shanghai 200092, China)

Abstract [Objective] In face of increasingly stringent sewage treatment discharge standards and continuously rising operational costs, leveraging intelligent technologies to achieve stable operation and energy conservation in wastewater treatment plants has become an urgent challenge for the industry. Given the limited adaptability of traditional mechanistic models in describing complex biological reaction processes, conducting data-driven state prediction research is of significant engineering importance. [Methods] This paper focused on the anaerobic-anoxic-oxic activated sludge process of a specific wastewater treatment plant and constructed a long short-term memory (LSTM) network state prediction model. By performing data preprocessing procedures such as historical operation data cleaning and normalization, a model input-output structure consistent with time-series characteristics was established. The model took influent water quality indices, reactor operational state variables, and control parameters as inputs, uncovering dynamic correlations within multivariate time-series data to achieve accurate prediction of key water quality parameters such as dissolved oxygen (DO) and mixed liquor suspended solids (MLSS). [Results] LSTM model significantly outperformed conventional recurrent neural networks and multilayer perceptrons in terms of prediction accuracy, stability, and robustness. Furthermore, appropriately increasing network complexity and the volume of training data could further enhance the predictive performance and generalization ability of the model. [Conclusion] This paper not only verifies the effectiveness and feasibility of deep learning method in time-series state prediction for

[收稿日期] 2025-12-03

[基金项目] 国家自然科学基金(52470109)

[通信作者] 沈浩(1977—), 男, 高级工程师, 主要从事污水厂优化控制与运行等工作, E-mail: sh_nbwater@126.com。

wastewater treatment but also provides a reliable predictive basis for biological reactor states in intelligent operation strategies such as feedforward compensation control and rolling optimization. Furthermore, it offers a feasible technical pathway for constructing data-driven closed-loop optimization control systems, contributing positively to promoting intelligent and low-carbon operation of wastewater treatment plants.

Keywords wastewater treatment plant (WWTP) deep learning long short-term memory (LSTM) network biological reactor state prediction

城市污水处理厂在维护水环境安全与推进碳中和战略中发挥着关键作用。然而,其运行面临进水水质剧烈波动、排放标准日益严苛以及能耗居高不下等多重挑战^[1],严重制约了整体效率。在污水处理过程中,活性污泥系统是非线性的复杂生物系统^[2]。传统控制算法未充分考虑当前控制改变对整体出水稳定性的影响,且存在滞后效应^[3],难以提前预知系统变化。另一方面,传统控制方式无法充分利用污水厂工艺运行过程中的监测数据,难以灵活实时调整控制策略。在保障出水达标和稳定运行的前提下,如何对生物反应过程水质参数及能耗情况进行预测,阐明进水、操作与运行状态三者之间的关系,并构建闭环优化控制策略,是亟待攻克的关键难点。

人工智能因其解决实际问题的强大能力而被引入环境领域。人工智能提供了数据驱动的环境问题的解决方案,使模型能够从统计学角度出发,从海量数据中挖掘潜在规律,而其中的深度学习模型具有强大的学习能力与非线性逼近能力^[4-5]。其中,循环神经网络(RNN)及其改进模型长短期记忆(LSTM)网络专为处理序列数据而设计。与传统前馈神经网络不同,如多层感知器(MLP)模型,LSTM通过其独特的“门控机制”(包括输入门、遗忘门和输出门)和“细胞状态”,能够有效捕捉时间序列中跨越长时间步的依赖关系,并缓解普通RNN中常见的梯度消失或爆炸问题。利用人工智能模型,可以在保障出水达标的前提下,对生物反应过程水质参数及污水处理过程中物耗、能耗情况进行预测,阐明进水、操作与出水三者之间的关系,为污水处理的智能化运营框架构建和优化控制提供新思路。

本文聚焦人工智能前沿理论与环境工程核心技术,构建污水处理厂过程模拟、预测及优化模型与方法体系,为智能控制技术的研发与推广提供理论支撑,从而显著提升管理水平,推动污水处理产业的绿色转型。

1 研究对象

以W市S污水处理厂厌氧-缺氧-好氧(AAO)活性污泥工艺下的生物反应池为研究对象,基于深度学习原理,利用实测运行数据,对8个独立运行的生物反应池逐一建模。通过LSTM捕捉水质参数的时序变化模式,并融入多历史时间步数据,深度挖掘控制变量(如曝气量与回流流量)与状态变量的动态关系,如溶解氧(DO)与混合液悬浮固体(MLSS),从而实现未来时间步状态变量的高精度预测。可在确保出水达标的前提下,精准预测生物反应过程的关键水质参数,揭示进水、操作与出水间的内在关联,进而实现基于预测的前馈控制与优化调整。

2 模型结构及模型训练

2.1 训练数据

本研究污水厂主要采用AAO工艺,设计流量为80万 m^3/d ,设计出水水质为一级A标准,生物反应池构筑物数为4组,1组2池,共计8个反应池,各反应池均可单独运行。结合案例污水厂的实际在线监测数据布点情况,采集了2021年—2024年共4年的污水处理厂生物反应池部分水质参数。进水参数包括总进水流量、水温、进水化学需氧量(COD)、进水悬浮物(SS)等水质参数。生物反应池部分水质参数包括DO、氧化还原电位(ORP)、氨氮、硝态氮以及MLSS浓度。控制参数包括曝气量、内外回流量;监测数据的采集频率为5 min/次。选取进水输入、状态输入、控制输入三类参数作为模型输入,并选取下一时刻(研究选取30 min为时间间隔)的状态变量作为模型的输出。输入与输出的具体参数选取内容如表1所示。

为消除不同输入数据值大小的差异对模型分析的影响,采用最小-最大归一化技术对数据进行预处理。该方法能够将不同量纲的数据缩放到统一区间 $[-1, 1]$,有利于梯度下降算法的稳定收敛,尤其适用于本研究中取值范围差异较大的多源时序数据。处理如式(1)。

表1 状态预测模型的输入、输出
Tab.1 Input and Output of the State Prediction Model

类别	数据项
进水输入	进水 COD
	进水温度
	进水 SS
状态输入	生反池 DO
	生反池 MLSS
	生反池 ORP
	生反池剩余泵流量
	生反池瞬时流量
控制输入	好氧段曝气量
	内回流流量
	外回流流量
状态输出	下一时刻反应池 DO
	下一时刻反应池 MLSS

$$y = 2 \times \frac{Y - Y_{\min}}{Y_{\max} - Y_{\min}} - 1 \quad (1)$$

其中： y ——归一化后的值，值处于 $[-1, 1]$ ；

Y ——原始数据中的某个数值，即需要归一化的原始输入数据；

Y_{\max} ——清洗后数据最大值，单位同于相应计算参数单位；

Y_{\min} ——清洗后数据最小值，单位同于相应计算参数单位。

在数据预处理阶段，首先对原始监测数据进行完整性检查，针对缺失值采用前后时刻线性插值法进行填补；对于明显偏离工艺运行范围的异常值（如 DO 瞬时骤变、MLSS 负值等），结合工艺知识予以剔除或平滑处理；为进一步降低高频噪声对模型训练的影响，对关键时序变量（如 DO、MLSS）采用滑动平均进行平滑，考虑到生物反应池存在时滞特点，本研究参考 AAO 反应中水力停留时间，采用 15 h 作为时间窗口长度。最终获得可用于模型训练的清洗后数据集。

数据集按时间顺序划分为训练集、验证集与测试集，比例分别为 70%、20% 与 10%。该划分方式保留了数据的时间连续性，符合时序预测任务的验证要求。

2.2 LSTM 模型结构

构建的 LSTM 模型将生物反应池状态变量、进水变量、控制变量的时间序列数据作为输入，来预测下一时刻反应池的状态变量，模型的具体数学形式

如式(2)。

$$Y_{t+\Delta t} = \text{LSTM}(X_t, X_{t-1}, \dots, X_{t-L} \mid a_t, a_{t-1}, \dots, a_{t-L}; r_t, r_{t-1}, \dots, r_{t-L}; \theta) \quad (2)$$

其中： X_t ——状态变量输入，包含 DO、MLSS、ORP；

t ——数据对应的时间节点；

r_t ——进水变量输入；

a_t ——控制变量输入；

L ——输入变量时间步长；

Y_t ——状态变量输出，包含下一时间步的反应池的 DO、MLSS 等状态；

θ ——LSTM 模型参数；

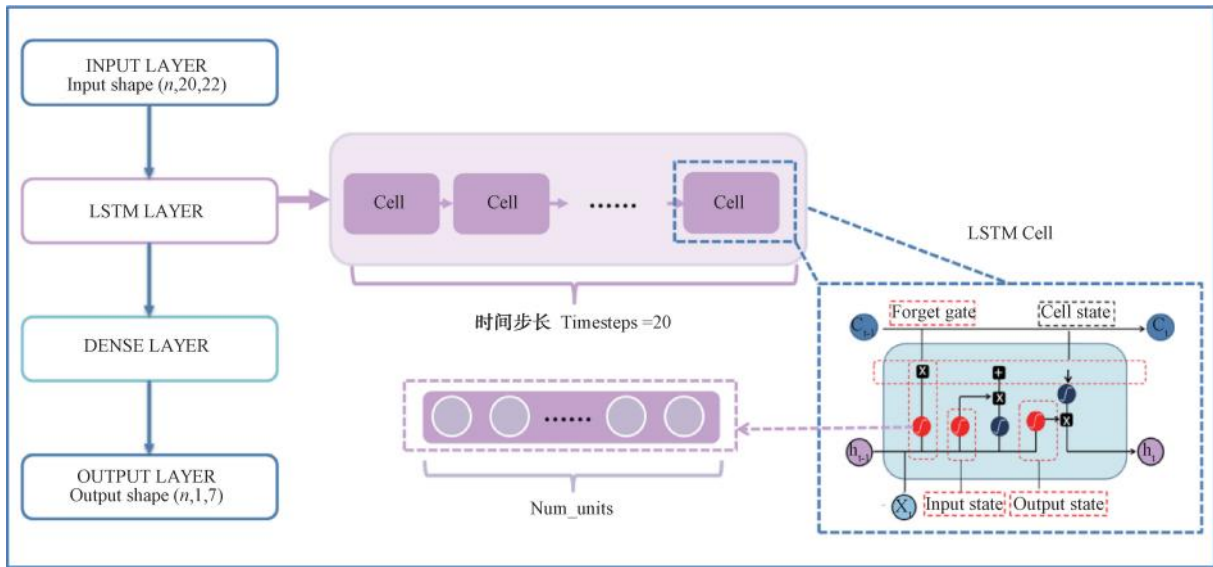
Δt ——预测下一时刻的时间间隔，min。

图 1 为 LSTM 模型示意图^[6]。模型包括输入层、LSTM 层，最终输出经过一个全连接的 Dense 层。LSTM 的结构超参数主要是 LSTM 单元的隐藏层神经元数量；为探究模型复杂度对预测性能的影响，并避免过拟合，本研究设计了从简到繁的 8 种 LSTM 结构进行对比。选取 1 号池为研究对象，构建了 8 种 LSTM 模型结构（命名为结构 1~8）来验证其预测性能。总数据量为本文 2.1 节提及的 2021 年—2024 年共 4 年污水厂生物反应池 5 min 频率的水质参数，包括总进水流量、水温、COD、SS、DO、ORP、曝气量、内外回流量等数据。为了比较数据集大小对结果影响，采用 2 种数据集，其中数据集 1 采用了总数据量的 1/2 数据，即 2021 年—2022 年 2 年数据进行训练，数据集 2 采用了总数据量的 1/3 数据，即 2021 年—2022 年 4 月共 16 个月数据进行训练。各结构的参数在预测试中逐步调整，如表 2 所示。

2.3 LSTM 训练过程

传统的神经网络训练方法通过数据与基于梯度的反向传播算法实现，也即在给定的数据范围内，通过最小化目标函数调整神经网络中的参数以达到训练的效果。本研究通过最小化经验误差实现对 LSTM 模型的训练。具体可以通过式(3)~式(6)的最优化问题表示，也即训练模型等同于求解该最优化问题。

$$\min \text{Loss} = \frac{1}{2} \sqrt{\frac{1}{N} \sum_{t=0}^T \sum_{i=1}^N \| Y_{t,i} - \bar{Y}_{t,i} \|^2} + \frac{\lambda}{2N} \sum_{\theta} \theta^2 \quad (3)$$



注: n —批次大小;INPUT LAYER—输入层;LSTM LAYER—长短期记忆网络层;DENSE LAYER—全连接层;OUTPUT LAYER—输出层;Input shape—输入数据;Output shape—输出数据;Cell—LSTM 单元;Timesteps—时间步长;Num_units—单元数量;LSTM Cell—LSTM 单元结构;Forget gate—遗忘门;Cell state—细胞状态;Input state—输入状态;Output state—输出状态。

图 1 LSTM 深度学习模型结构

Fig. 1 Structure of the LSTM Deep Learning Model

表 2 LSTM 模型结构

Tab. 2 Structure of LSTM Model

训练集	模型结构	LSTM 隐藏层神经元数量
数据集 1 (总数据量的 1/2)	结构 1	15
	结构 2	20
	结构 3	25
	结构 4	30
数据集 2 (总数据量的 1/3)	结构 5	15
	结构 6	20
	结构 7	25
	结构 8	30

$$Y_{t+1,i} = \text{LSTM} \left(\overline{X_{t,i}}, \overline{X_{t-1,i}}, \dots, \overline{X_{t-L,i}} \mid \overline{a_{t,i}}, \overline{a_{t-1,i}}, \dots, \overline{a_{t-L,i}}, \overline{r_{t,i}}, \overline{r_{t-1,i}}, \dots, \overline{r_{t-L,i}}, \theta_1, \theta_2 \right) \quad (4)$$

$$Y_{t+1,i} = \text{Dense} \left(\overline{h_{t+1,j}} \mid \theta_2 \right) \quad (5)$$

$$\overline{h_{t+1,j}} = \text{LSTM}_{\text{layer}} \left(\overline{h_{t,j}} \mid \overline{a_{t,j}}, \overline{r_{t,j}}, \overline{h_{t,j}}, \theta_1 \right) \quad (6)$$

其中: λ ——正则项系数;

$Y_{t,i}$ —— t 时刻模型预测输出值;

$\overline{X_{t-L,i}}, \overline{a_{t-L,i}}, \overline{r_{t-L,i}}$ ——对应 $t-L$ 时刻收集的状态、控制、和进水变量的数据;

$\overline{Y_{t,i}}, \overline{X_{t,i}}, \overline{a_{t,i}}, \overline{r_{t,i}}$ ——收集的输出、状态、控制、进水变量的数据;

N ——数据组数,每组用计数器 i 表示;

T ——时间节点总数;

Dense——全连接层;

$\text{LSTM}_{\text{layer}}$ ——LSTM 层;

θ_1, θ_2 ——LSTM 层、Dense 层的训练参数;

$\overline{h_{t+1,j}}$ ——LSTM 层通过数据计算得到的时间序列隐变量。

通过求解该优化模型,即可获得神经网络参数 θ_1, θ_2 , 由此将 θ_1, θ_2 引入 LSTM, 即可获得训练后的神经网络模型。

利用 LSTM 神经网络对污水厂生物反应池进行预测时,同时参考污水厂实际运行经验、水力停留时间,选取用于 LSTM 网络预测的时间间隔(步长)为 30 min,总步长数为 20,即使用污水厂前 10 h 的进水水质等监测数据来预测未来 30 min 的污水厂生物反应池水质参数情况。

LSTM 模型各结构的超参数在预测中逐步调整,如表 3 所示。

神经网络模型的优化器采用自适应矩估计(Adam)优化器,Adam 优化器由反向传播算法发展而来,应用广泛、鲁棒性强。Adam 优化器根据参数

表 3 LSTM 模型训练超参数

Tab. 3 Training Hyperparameters of the LSTM Model

模型参数项	参数取值/设置
输入数据格式	[n, 20, 22]
输出数据格式	[n, 7]
激活函数	tanh
初始学习率	0.000 1
Epoch	100
损失函数	均方误差(MSE)

的偏导数方法来进行参数更新,通过自适应调整学习速率,在保证后损失函数快速收敛的前提下,实现梯度的快速下降。本研究采用网格搜索对初始学习

表 4 1~8 号生化反应池各模型预测 MSE 和 NSE

Tab. 4 MSE and NSE Predictions by Each Model for Biochemical Reactors No. 1-No. 8

生反池	MLP 模型		RNN 模型		LSTM 模型	
	MSE	NSE	MSE	NSE	MSE	NSE
1 号池	0.087	0.925	0.089	0.921	0.080	0.936
2 号池	0.088	0.957	0.079	0.965	0.065	0.977
3 号池	0.108	0.957	0.059	0.985	0.044	0.992
4 号池	0.120	0.862	0.100	0.981	0.092	0.990
5 号池	0.071	0.970	0.060	0.979	0.050	0.985
6 号池	0.063	0.972	0.053	0.980	0.043	0.987
7 号池	0.077	0.955	0.065	0.968	0.054	0.978
8 号池	0.067	0.974	0.057	0.981	0.047	0.988

污水处理生物反应工艺单元的整体 MSE 在合理范围之内,且预测结果通过 NSE 计算的值接近为 1。由表 4 可知,3 种模型的预测效果都较好。进一步分析发现,不同反应池的模型预测性能存在差异,这可能与各池的进水负荷分布、曝气均匀性、污泥回流分配等实际运行特性有关。例如,3 号池与 4 号池的预测误差相对较高,可能与这 2 组池体位于进水端,水质波动更大有关。

其中,LSTM 网络的预测结果较其他模型更加准确,预测稳定性也更高。分析其原因在于,LSTM 通过门控机制(输入门、遗忘门、输出门)和细胞状态,能够有效捕捉时间序列中的长期依赖关系,缓解了 RNN 的梯度消失问题。同时,LSTM 复杂的网络结构赋予其更强的非线性拟合能力,能够更好地处理污水处理过程中复杂的动态非线性关系。本研究采用的 Adam 优化器能够自适应调整学习率,加速模型收敛,进一步提升训练效率与预测精度。

进一步分析了 LSTM 预测结果与真实值之间的

率进行调优,最终选定 0.000 1,模型收敛稳定且性能最佳。训练轮数(Epoch)通过早停法确定。模型搭建及训练使用 Keras 库完成。为了进一步比较预测的结果,判断模型性能,本文将 LSTM 与 MLP、RNN 进行比较,并采用均方误差(MSE)和纳什均衡系数(NSE)评估其预测结果。

3 模型结果分析

上述各个 LSTM 模型在训练之后,对不同时间段的 AAO 工艺过程的水质参数进行预测,得到 LSTM 模型结构在不同生化反应池中的 MSE 和 NSE 如表 4 所示。

差距,以 1 号池为例,其预测曲线如图 2 所示。由图 2 可知,预测结果能准确捕捉 MLSS 和 DO 的变化趋势。DO 除个别极值点外,其他序列都预测较为准确。而相比于 MLSS,DO 由于变化幅度较大,预测精度不如 MLSS 的高,但变化趋势基本一致。




图 2 1 号池 LSTM 预测效果

Fig. 2 LSTM Predictive Effect for No. 1 Reactor

进一步又分析了不同数据训练集在不同模型结构下的预测结果。针对单个生物反应池,不同训练

数据组及 LSTM 模型结构的预测结果如表 5 所示。结果显示,随着 LSTM 结构复杂度增加,预测效果越好。同时本研究在损失函数内添加了正则化项,以防出现过拟合现象。此外,使用 2 种训练数据集进行了试验,结果显示:训练数据越多,对于水质参数的预测效果越好。

表 5 1 号生化反应池 LSTM 模型在不同数据组及结构时的 MSE 和 NSE

Tab. 5 MSE and NSE of the LSTM Model for Biochemical Reactor No. 1 under Different Data Sets and Structures

训练集	模型结构	LSTM 层节点数	MSE	NSE
数据集 1 (总数据量的 1/2)	结构 1	15	0.083	0.932
	结构 2	20	0.082	0.933
	结构 3	25	0.081	0.935
	结构 4	30	0.080	0.936
数据集 2 (总数据量的 1/3)	结构 5	15	0.085	0.928
	结构 6	20	0.085	0.929
	结构 7	25	0.083	0.932
	结构 8	30	0.082	0.933

4 结论与展望

本文提出了一种基于历史数据构建的 LSTM 深度学习神经网络模型,用于 AAO 生物反应系统的关键水质参数状态预测。该模型融合进水变量、反应池状态变量与控制变量,深度挖掘了工艺参数间的动态时序关联,将其从传统的状态预测模型转化为可服务于控制的过程预测模型,为污水处理厂的实时优化控制与节能运行提供了直接的预测信息输入。

(1)模型验证结果表明,LSTM 在预测精度与稳定性上均优于 RNN 与 MLP。主要得益于 LSTM 门控结构与长期依赖捕捉能力,能更好地适应污水处理中动态、非线性的时序数据特征,显著提升了对 DO、MLSS 等关键参数的预测性能。

(2)通过对比 8 种不同复杂度的 LSTM 结构发现,适当增加网络复杂度有助于增强模型对非线性特征的拟合能力,而引入正则化可有效避免过拟合。此外,模型表现随训练数据量的增加而持续改善,证明利用海量级历史数据可进一步提升状态预测的准确性。

(3)研究存在的局限性:模型可解释性不足,对

数据质量依赖较高,未融合生化机理,且尚未实现在线闭环验证。未来可通过引入注意力机制、构建机理-数据融合的“灰箱”模型,并部署至实际系统进行滚动预测与控制验证,以提升模型的可靠性、泛化能力及工程实用性。

本研究构建了高精度状态预测模型,为实现从“预测”到“控制”的污水处理厂闭环优化提供了可靠基础。基于模型的输出,可进一步开发前馈补偿、滚动优化等智能控制策略,例如利用预测 DO 值提前调节曝气量以抑制进水扰动,或结合预测 MLSS 优化回流系统以降低能耗,从而推动污水处理系统由被动响应向主动优化的运行模式转型。

参考文献

- [1] Sin G, Al R. Activated sludge models at the crossroad of artificial intelligence—A perspective on advancing process modeling[J]. *npj Clean Water*, 2021, 4: 16. DOI: 10.1038/s41545-021-00106-5.
- [2] 王丽, 刘丽红, 陈明月, 等. 污水处理智能控制技术及其在精准曝气中的应用[J]. *净水技术*, 2022, 41(s1): 1-7, 19. Wang L, Liu L H, Chen M Y, et al. Wastewater treatment intelligent control technologies and application in accurate aeration[J]. *Water Purification Technology*, 2022, 41(s1): 1-7, 19.
- [3] 吴菁. 污水处理非稳态特性下核建模方法关键问题的研究[D]. 广州: 华南理工大学, 2020. Wu J. Study on kernel function modeling method for unsteady process of wastewater treatment[D]. Guangzhou: South China University of Technology, 2020.
- [4] 殷逢俊, 徐泽宇, 刘鸿. 基于机理模型与数据模型融合的污水处理智能控制系统构建思路[J]. *环境工程*, 2022, 40(6): 138-144. Yin F J, Xu Z Y, Liu H. Thinking on constructing an intelligent control scheme of wastewater treatment based on the combination of mechanism and data-driven models [J]. *Environmental Engineering*, 2022, 40(6): 138-144.
- [5] Zhu Z A, Dong S K, Zhang H, et al. Bayesian optimization-enhanced reinforcement learning for self-adaptive and multi-objective control of wastewater treatment [J]. *Bioresource Technology*, 2025, 421: 132210. DOI: 10.1016/j.biortech.2025.132210.
- [6] Elkiran G, Nourani V, Abba S I. Multi-step ahead modelling of river water quality parameters using ensemble artificial intelligence-based approach [J]. *Journal of Hydrology*, 2019, 577: 123962. DOI: 10.1016/j.jhydrol.2019.123962.